

Труды МАИ. 2022. № 123
Trudy MAI, 2022, no. 123

Научная статья
УДК 519.87
DOI: [10.34759/trd-2022-123-17](https://doi.org/10.34759/trd-2022-123-17)

ПРИМЕНЕНИЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧ ПРОГНОЗИРОВАНИЯ ДВИЖЕНИЯ НАЗЕМНЫХ ОБЪЕКТОВ

Дмитрий Юрьевич Соколов

Национальный центр вертолётостроения им. М.Л. Миля и Н.И. Камова,
Томилино, Московская область, Россия

dsokolov@mi-helicoptр.ru

Аннотация. Статья посвящена рассмотрению применения искусственной нейронной сети для решения задач прогнозирования движения наземных объектов. Предлагается новый подход к построению архитектуры и использованию способов обучения нейронной сети применительно к специфике задачи прогнозирования траектории движения в пространстве параметров. Дается оценка различным способам обучения, и определяются оптимальные параметры коэффициентов, используемых в алгоритмах обучения нейронной сети.

Задача прогнозирования движения наземных объектов является актуальной, как применительно к действиям боевых вертолётов, в случае наведения их на подвижную маневрирующую цель, так и применительно к гражданской авиации, в том числе беспилотной, когда необходимо отслеживать различные наземные объекты.

Применение известных типов нейронных сетей для решения задачи прогнозирования движения наземного объекта (как образа траектории движения объекта в целом) не учитывает последовательность прохождения объектом точек траектории, что является важной информацией для решения задачи прогнозирования движения объекта. Дополнительная обработка данных и математические преобразования позволяют решить задачу учета информации о последовательности прохождения точек, однако это увеличивает общую сложность вычислений и может нивелировать эффективность применения НС для решения задачи прогнозирования.

В статье предложена некоторая архитектура построения нейронной сети, в которой каждый нейрон соответствует отдельной точке или области пространства, где осуществляется движение объекта. Данная архитектура предполагает построение рекуррентной нейронной сети, что накладывает некоторые особенности на процесс обучения и последующего использования нейронной сети. Так процесс обучения рекуррентной нейронной сети должен быть итерационным до достижения некоторого минимума целевой функции.

В статье рассмотрены различные способы обучения нейронной сети и определены наиболее подходящие с точки зрения минимизации ошибки и длительности циклов обучения.

В данной статье рассмотрено движение в двух координатах (на плоскости). Однако в общем случае пространство параметров в которых происходит движение может содержать большее количество координат (гиперплоскость). Обучение и использование пространственно-закрепленной НС для прогнозирования движения в

пространстве параметров любого количества координат будет осуществляться аналогичным способом, как и для прогнозирования движения на плоскости.

В перспективе предложенный вариант построения нейронной сети может быть использован для прогнозирования движения различных, в том числе абстрактных объектов в многомерном гиперпространстве их параметров.

Ключевые слова: нейронные сети, траектория движения, прогнозирование движения объекта, пространство параметров, наземный объект, архитектура нейронной сети, алгоритм обучения нейронной сети

Для цитирования: Соколов Д.Ю. Применение искусственной нейронной сети для решения задач прогнозирования движения наземных объектов // Труды МАИ. 2022. № 123. DOI: [10.34759/trd-2022-123-17](https://doi.org/10.34759/trd-2022-123-17)

APPLICATION OF ARTIFICIAL NEURAL NETWORK FOR SOLVING PROBLEMS OF FORECASTING THE MOVEMENT OF GROUND OBJECTS

Dmitriy Yu. Sokolov

JSC «Helicopters Mil&Kamov»,

Moscow region, Tomilino, Russia

dsokolov@mi-helicopters.ru

Abstract. The article deals with considering the artificial neural network application for solving the problems of the ground-based object motion predicting. It proposes a new approach to the neural network architecture elaboration and applying its training techniques as applied to the specifics of the problem of motion trajectory prediction in the

space of parameters. Estimation of various training techniques is given, and optimal parameters of coefficients, employed in the neural network training algorithms are determined.

The task of the ground-based objects motion predicting is up-to-date as applied to both combat helicopters actions, in the case of their aiming at a moving maneuvering target, and civil aviation, including unmanned aircraft, when it is necessary to track various ground objects.

Application of the known types of neural networks for solving the problem of the motion predicting of a ground object (as an image of the object trajectory en masse) does not account for the sequence of passing the trajectory points by the object, which is an important information for solving the problem of the object motion predicting. Additional data processing and mathematical transforms allow solving the problem of accounting for the information on the sequence of passing points. However, this increases the overall complexity of calculations and may level the effectiveness of NN application for solving the forecasting problem.

The article proposes a certain architecture for a neural network building, in which each neuron corresponds to a separate point or region of space where the movement of an object being performed. This architecture assumes elaboration of a recurrent neural network, which imposes certain specifics on the training process and subsequent application of the neural network. Thus, the training process of a recurrent neural network should be iterative until a certain minimum of the objective function is reached.

The article discusses various ways of a neural network training and determines the most suitable ones from the standpoint of minimizing the errors and duration of the training cycles.

This article considers the movement in two coordinates (on a plane). However, in the general case, the space of parameters, in which the movement occurs, may contain greater number of coordinates (hyperplane). Both training and application of predictive neural network for the motion prediction in the space of parameters with any number of coordinates will be realized by the technique similar to the one for the motion on the plane.

In the prospect, the proposed version of a neural network building may be applied to predict the movement of various objects, including the abstract ones in a multidimensional hyperspace of their parameters.

Keywords: neural networks, motion trajectory, object motion prediction, parameter space, ground object, neural network architecture, neural network training algorithm

For citation: Sokolov D.Yu. Application of artificial neural network for solving problems of forecasting the movement of ground objects. *Trudy MAI*, 2022, no. 123. DOI: [10.34759/trd-2022-123-17](https://doi.org/10.34759/trd-2022-123-17)

Одной из задач, возникающих при создании вертолетных комплексов нового поколения, в том числе беспилотных и робототехнических, является задача прогнозирования местоположения, а также состояния вертолетного комплекса и траектории его движения в пространстве параметров, а также движения связанных с

ним объектов на местности, тем или иным образом связанных с целями функционирования вертолетного комплекса [1-4].

Задачи прогнозирования движения наземных объектов в настоящее время решаются различными методами [5]. В основном для этого используются методы математического моделирования, интерполяции и экстраполяции по известным точкам местоположения объекта. Однако, такие методы эффективны только при движении объекта по траектории близкой к линейной зависимости или полиномиальной [6]. На практике такое движение объекта встречается редко, поэтому требуется новый методический подход, который не будет привязан к необходимости построения строгих математических зависимостей.

Для решения задачи прогнозирования движения наземного объекта, возможно использовать нейросетевые технологии, которые эффективно решают задачу распознавания различных образов, к которым можно отнести траекторию движения различных объектов (наземных и воздушных) [7,8]. При этом применение нейросетевых методов по сравнению с другими способами распознавания образов и аппроксимации данных является более предпочтительным [9-11].

Применение известных типов нейронных сетей (НС) [12] для решения задачи прогнозирования движения наземного объекта (как образа траектории движения объекта в целом) не учитывает последовательность прохождения объектом точек траектории, что является важной информацией для решения задачи прогнозирования движения объекта [13]. Дополнительная обработка данных и математические преобразования позволяют решить задачу учета информации о последовательности прохождения точек [14], однако это увеличивает общую

сложность вычислений и может нивелировать эффективность применения НС для решения задачи прогнозирования.

Архитектура нейронной сети для прогнозирования движения объекта

Предлагается архитектура НС, которая будет учитывать информацию о точках траектории прохождения объекта на некоторой плоскости или области пространства. Предлагаемая архитектура (или топология) НС подразумевает ее построение определенным образом, так что бы каждый отдельный нейрон соответствовал определенной точке на плоскости или области пространства, в котором осуществляется движение объекта. Таким образом НС является как бы закрепленной на определенном участке местности или области пространства или по другому – *пространственно закрепленная НС*. Простой пример топологии пространственно закрепленной НС схематично представлен на рис.1. НС представлена в виде сетки на плоскости, разбитой на 9 участков (3x3). На пересечении разделяющих линий сетки (узлах) находятся нейроны – 9 нейронов при таком варианте разбиения.




Рис.1. Топология пространственно закрепленной НС для прогнозирования движения объектов на некоторой плоскости

Особенностью архитектуры, предлагаемой НС является то, что выход каждого нейрона соединяется с входами всех нейронов НС (рис.2), т.е. сеть является рекуррентной. Для рекуррентных сетей характерно то, что входной вектор является одновременно выходом на нулевом шаге итерации вычислений НС [12].

$$\vec{X}^1 = \vec{Y}^0 \quad (1)$$

где \vec{X}^1 – вектор входных данных для первого шага вычислений;

\vec{Y}^0 – вектор выходных данных на нулевом шаге итерации.




Рис. 2. Архитектура пространственно закрепленной НС для прогнозирования движения объектов на некоторой плоскости

Процесс функционирования пространственно-закрепленной нейронной сети для прогнозирования движения объекта

Далее более детально опишем и проанализируем процесс функционирования пространственно-закрепленной НС по прогнозированию движения объекта.

На вход сети подается набор входных данных $(x_1 \dots x_{16})$, который соответствует некоторой известной части траектории движения объекта.

Количество элементов во входном наборе данных (векторе) равно количеству нейронов в НС, поскольку сеть является рекуррентной. Каждый элемент входного вектора соответствует определенному нейрону, который в свою очередь соответствует определенной точке на плоскости. Значение элемента входного вектора показывает принадлежность соответствующей ему точки на плоскости к траектории движения объекта следующим образом:

$$x_i = \begin{cases} 1 & \text{– точка принадлежит траектории} \\ 0 & \text{– точка не принадлежит траектории} \end{cases} \quad (2)$$

где x_i – элемент вектора входных данных.

На первом шаге итерации НС ($k=1$) получим некоторый набор (вектор) выходных данных $(y_1^1 \dots y_{16}^1)$ по которому определяется нейрон-победитель ($N_{i \text{ поб}^1}$) с наибольшим выходным значением ($y_{i \text{ поб}^1}$). Элементу выходного вектора с наибольшим значением присваивается значение 1, остальным элементам присваивается значение 0. В результате получим следующий выходной вектор на 1-м шаге итерации:

$$\vec{Y}^1 = O_{\text{НС}}(\vec{X}^1) \quad (3)$$

где $O_{\text{НС}}$ – оператор вычислений НС;

$$\vec{Y}^1 = \begin{bmatrix} y_1^1 \\ \cdot \\ y_{i \text{ поб}}^1 \\ \cdot \\ y_{16}^1 \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 1 \\ \cdot \\ 0 \end{bmatrix}$$

Нейрон-победитель будет соответствовать точке на плоскости (рис.1) в которой прогнозируется местонахождение объекта в результате движения за промежуток времени, соответствующий одному шагу итерации.

Прогнозирование на последующих шагах итерации происходит следующим образом. Входной вектор, соответствующий известной части траектории, логически складывается с полученным на 1-м шаге итерации выходным вектором:

$$\vec{X}^2 = \vec{X}^1 \vee \vec{Y}^1 \quad (4)$$

или

$$\begin{bmatrix} x_1^2 \\ \cdot \\ x_i^2 \\ \cdot \\ x_{16}^2 \end{bmatrix} = \begin{bmatrix} x_1^1 \vee y_1^1 \\ \cdot \\ x_i^1 \vee y_{i \text{ поб}}^1 \\ \cdot \\ x_{16}^1 \vee y_{16}^1 \end{bmatrix} = \begin{bmatrix} x_1^1 \vee 0 \\ \cdot \\ x_i^1 \vee 1 \\ \cdot \\ x_{16}^1 \vee 0 \end{bmatrix}$$

где \vec{X}^2 – вектор входных данных для 2-го шага итерации;

\vee – оператор логического «или».

Такое действие позволяет дополнить входной образ части траектории движения спрогнозированным значением для прогнозирования на следующем шаге по дополненному образу траектории.

С учетом (1), выражение (4) можно представить:

$$\vec{X}^2 = \vec{Y}^0 \vee \vec{Y}^1 \quad (5)$$

Далее на втором и последующих шагах итерации НС, вычисления повторяются аналогично, как и на первом шаге. Входной вектор для k -го шага вычислений будет определяться аналогично (5):

$$\vec{X}^k = \vec{Y}^{k-2} \vee \vec{Y}^{k-1} \quad (6)$$

После k -го шага вычислений получим выходной вектор:

$$\vec{Y}^k = O_{\text{НС}}(\vec{X}^k) \quad (7)$$

Прогнозируемая точка местонахождения объекта на период времени, соответствующий k -му шагу вычислений, будет соответствовать нейрону победителю на k -м шаге вычислений НС.

В качестве модели нейрона НС для прогнозирования движения объекта может использоваться нейрон с сигмоидальной, линейной или ступенчатой функцией активации [12].

Сигмоидальная функция активации описывается как:

$$f(u) = \frac{1}{1+e^{-\beta u}} \quad (8)$$

Ступенчатая функция активации описывается как:

$$f(u) = \begin{cases} 1 & \text{для } u \geq 0 \\ 0 & \text{для } u < 0 \end{cases} \quad (9)$$

Где u определяется следующим образом:

$$u = \sum_{i=0}^N w_i \cdot x_i \quad (10)$$

где w_i – вес i -го входа нейрона;

x_i – значение i -го входа нейрона;

N – количество входов нейрона.

Нулевой член входного вектора нейрона x_0 совместно с нулевым весом w_0 формируют сигнал поляризации или определяют порог срабатывания нейрона. При этом x_0 всегда равен 1.

Параметр β в соотношении (8) определяет степень кривизны функции активации. При $\beta = \infty$ функция становится ступенчатой.

График сигмоидальной и ступенчатой функций представлен на рис.3.




Рис. 3. Графики сигмоидальной и ступенчатой функций активации

Обучение НС для прогнозирования движения объекта производится на основе статистического набора обучающих данных (траекторий движения) по принципу обучения с учителем. Набор обучающих данных должен пройти предварительную обработку для определения каждой траектории в соответствие некоторой последовательности точек на плоскости, каждой из которых, в свою очередь, соответствует определенный нейрон НС. Далее формируется обучающий входной вектор, в котором элементы, соответствующие полученному набору точек принимаются равными 1, остальные элементы равными 0.

$$\vec{D}_{об} = \begin{bmatrix} d_1 \\ \cdot \\ d_i^{1\text{тр}} \\ \cdot \\ d_j^{M\text{тр}} \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 1 \\ \cdot \\ 1 \\ \cdot \\ 0 \end{bmatrix} \quad (11)$$

где $\vec{D}_{об}$ – обучающий вектор;

M – количество точек траектории.

Обучение проводится в несколько этапов, на каждом из которых происходит настройка НС под каждую следующую точку обучающей траектории. Для этого входной обучающий вектор преобразуется в множество обучающих пар входных и выходных субвекторов по следующему принципу.

Первая пара обучающих субвекторов формируется следующим образом.

Первый входной субвектор содержит один единичный элемент, соответствующий первой точке траектории и остальные нулевые элементы:

$$\vec{X}_{об}^1 = \begin{bmatrix} d_1 \\ \cdot \\ d_i^{1\text{тр}} \\ \cdot \\ \cdot \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 1 \\ 0 \\ \cdot \\ \cdot \\ 0 \end{bmatrix} \quad (12)$$

Первый выходной субвектор содержит один единичный элемент, соответствующий второй точке траектории и остальные нулевые элементы:

$$\vec{Y}_{06}^1 = \begin{bmatrix} d_1 \\ \cdot \\ \cdot \\ d_i^{2\text{тр}} \\ \cdot \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 0 \\ 1 \\ \cdot \\ \cdot \\ 0 \end{bmatrix} \quad (13)$$

Второй входной субвектор содержит два единичных элемента, соответствующих первой и второй точкам траектории и остальные нулевые элементы:

$$\vec{X}_{06}^2 = \begin{bmatrix} d_1 \\ \cdot \\ d_i^{1\text{тр}} \\ d_i^{2\text{тр}} \\ \cdot \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 1 \\ 1 \\ \cdot \\ \cdot \\ 0 \end{bmatrix} \quad (14)$$

Второй выходной субвектор содержит один единичный элемент, соответствующий третьей точке траектории и остальные нулевые элементы:

$$\vec{Y}_{06}^2 = \begin{bmatrix} d_1 \\ \cdot \\ \cdot \\ \cdot \\ d_i^{3\text{тр}} \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 0 \\ 0 \\ 1 \\ \cdot \\ 0 \end{bmatrix} \quad (15)$$

Последующие обучающие субвектора формируются аналогичным образом с добавлением к каждому последующему входному субвектору одного единичного элемента, соответствующего следующей точке траектории. Выходной обучающий субвектор также содержит один единичный элемент соответствующий следующей точке траектории.

$$\vec{X}_{об}^m = \begin{bmatrix} d_1 \\ \cdot \\ d_i^{1тр} \\ d_i^{2тр} \\ \cdot \\ d_i^{m тр} \\ \cdot \\ d_i^{M тр} \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 1 \\ 1 \\ \cdot \\ 1 \\ 0 \\ 0 \\ \cdot \\ 0 \end{bmatrix} \quad \vec{Y}_{об}^m = \begin{bmatrix} d_1 \\ \cdot \\ d_i^{1тр} \\ d_i^{2тр} \\ \cdot \\ d_i^{m тр} \\ \cdot \\ d_i^{m+1 тр} \\ \cdot \\ d_i^{M тр} \\ \cdot \\ d_{16} \end{bmatrix} = \begin{bmatrix} 0 \\ \cdot \\ 0 \\ 0 \\ \cdot \\ 0 \\ 1 \\ 1 \\ \cdot \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (16)$$

Общее количество обучающих пар субвекторов будет на единицу меньше количества точек траектории: $(M-1)$.

Обучение прогнозирующей НС может осуществляться с использованием одного из обучающих алгоритмов, которые позволят настроить НС таким образом, чтобы на ее выходе были результаты с наименьшей суммарной ошибкой для всего набора обучающих пар векторов. Суммарную ошибку для набора из K обучающих пар векторов можно определить следующим образом [12]:

$$\varepsilon = \frac{1}{2} \cdot \sum_{k=1}^K \sum_{i=1}^N (y_i^k - y_{iоб}^k)^2 \quad (17)$$

где ε – суммарное значение ошибки НС;

y_i^k – значения i -го элемента k -го выходного вектора, полученного на выходе НС;

$y_{iоб}^k$ – значения i -го элемента k -го обучающего выходного вектора.

В качестве алгоритма обучения прогнозирующей НС можно использовать модифицированное правило Хебба. Корректировка весов НС в модифицированном правиле Хебба происходит следующим образом [12]:

$$w_{ij}(k + 1) = w_{ij}(k) \cdot (1 - \gamma) + \Delta w_{ij} \quad (18)$$

где $w_{ij}(k)$ – вес между выходом i -го и входом j -го нейрона на k -м шаге обучения НС;

γ – коэффициент забывания, выбирается из интервала (0,1);

Δw_{ij} – приращение веса.

$$\Delta w_{ij} = \eta \cdot y_i \cdot d_j \quad (19)$$

где y_i – выход i -го нейрона (i -й вход j -го нейрона);

d_j – ожидаемый выход j -го нейрона;

η – коэффициент обучения, выбирается из интервала (0,1).

Компьютерное моделирование пространственно-закрепленной нейронной сети для прогнозирования движения объекта

Для определения практической возможности обучения и тестирования предложенной пространственно закрепленной НС, было проведено ее компьютерное моделирование.

Компьютерные эксперименты проводились для прогнозирования трех траекторий, содержащих по три точки и располагающихся на пространственно закрепленной НС размером 3x3, состоящей из 9 нейронов (рис. 4). В качестве модели нейрона использовался нейрон с линейной функцией активации.




Рис. 4. Траектории на пространственно закрепленной НС, содержащей 9 нейронов

Компьютерные эксперименты по обучению сети по правилу Хебба показали эффективность ее работы только при определенной последовательности подачи обучающих субвекторов, а именно начиная с последних сформированных пар (16) и заканчивая первой обучающей парой (12).

Обучение прогнозирующей НС по модифицированному правилу Хебба начинается с обнуления всех весов нейронов. Коэффициент обучения η задается равным 1. Обучение достаточно провести в один цикл, сохраняя последовательность подачи обучающих субвекторов от последних пар к первым.

Важным является вопрос выбора коэффициента забывания γ . Компьютерные эксперименты по тестированию обученной прогнозирующей НС показали влияние коэффициента забывания γ на правильность прогнозирования в зависимости от количества точек траектории.

На рис. 5 представлен график зависимости максимального количества точек траектории M_{max} , при котором осуществляется правильное прогнозирование НС, от коэффициента забывания γ .




Рис. 5. Зависимость максимального количества точек траектории от коэффициента забывания при обучении по правилу Хебба

Полученная зависимость показывает, что для эффективного обучения пространственно-закрепленной НС по модифицированному правилу Хебба, коэффициент забывания должен быть в интервале от 0.5 до 1, не включая данные значения. При этом, чем больше точек маршрута, под который обучается сеть, тем больше должно быть значение коэффициента забывания.

Другим алгоритмом обучения прогнозирующей НС может быть правило Видроу-Хоффа, которое является обобщением правила персептрона. Корректировка весов НС в алгоритме Видроу-Хоффа происходит следующим образом [12]:

$$w_{ij}(k + 1) = w_{ij}(k) + \Delta w_{ij} \quad (20)$$

$$\Delta w_{ij} = \eta \cdot y_i \cdot (d_j - y_j) \quad (21)$$

где y_i – выход i -го нейрона (i -й вход j -го нейрона);

y_j – выход j -го нейрона;

d_j – ожидаемый выход j -го нейрона.

Обучение прогнозирующей НС по правилу Видроу-Хоффа начинается с присвоения случайных значений весов нейронов. Обучение необходимо проводить в несколько циклов. Порядок подачи обучающих субвекторов при этом значения не имеет.

Существенным вопросом для эффективности обучения пространственно-закрепленной НС по правилу Видроу-Хоффа является выбор коэффициента обучения η .

На рис. 6 показана зависимость суммарной ошибки пространственно-закрепленной НС ε , полученной после 10 циклов обучения, от коэффициента обучения η .

На рис. 7 показана зависимость требуемого количества циклов обучения $K_{цикл}$ для достижения суммарной ошибки меньше 0.1, от коэффициента обучения.




Рис. 6. Зависимость суммарной ошибки после 10 циклов обучения от коэффициента обучения при обучении по правилу Видроу-Хоффа




Рис. 7. Зависимость требуемого количества циклов обучения для достижения суммарной ошибки меньше 0.1 от коэффициента обучения при обучении по правилу Видроу-Хоффа

Полученные зависимости показывают, что обучение по правилу Видроу-Хоффа наиболее эффективно с точки зрения суммарной ошибки и количества циклов обучения при значениях коэффициента обучения находящихся в диапазоне (0.2, 0.4). При значениях коэффициента обучения более 0.5, не удастся достигнуть суммарной ошибки менее 0.1 при любом сколь угодно большом количестве циклов обучения. В то же время уместно предположить, что при больших значениях количества нейронов пространственно-закрепленной НС и количества точек траекторий, эффективное значение коэффициента обучения будет снижаться.

Еще одним возможным способом обучения пространственно-закрепленной НС является обучение, схожее с алгоритмом Кохонена. В алгоритмах Кохонена нейрон-победитель и все нейроны, лежащие в некоторой его окрестности, подвергаются корректировке в направлении входного вектора. В алгоритме обучения пространственно-закрепленной НС по типу алгоритма Кохонена нейрон-победитель определяется не в результате конкуренции, а задается в соответствии со

следующей прогнозируемой точкой на плоскости. Вес нейрона-победителя корректируется следующим образом:

$$w_{ij}(k + 1) = w_{ij}(k) + \eta \cdot y_i \quad (22)$$

Коэффициент обучения η для нейрона-победителя будет принимать значения в диапазоне $[0.1, 1]$.

Для нейронов, находящихся в окрестности нейрона-победителя проводится также корректировка весов по соотношению 22. При этом коэффициент обучения η будет уменьшаться с увеличением расстояния между нейроном и нейроном-победителем R . Зависимость η от R может быть различной, например следующего вида:

$$\eta_j = \begin{cases} 1 - \frac{R_j}{R_{\text{окр}}} & \text{для } R_j \leq R_{\text{окр}} \\ 0 & \text{для } R_j > R_{\text{окр}} \end{cases} \quad (23)$$

где R_j – расстояние между j -м нейроном и победителем;

$R_{\text{окр}}$ – окрестность влияния нейрона-победителя.

Особенностью пространственно закрепленной НС, в отличие от карт Кохонена, является то что входными данными для нее будут значения выходов нейронов на предыдущем шаге прогнозирования. Для того чтобы пространственно закрепленной НС аппроксимировала входные данные всех обучающих пар субвекторов, необходимо корректировать веса нейронов не только в окрестности нейрона-победителя, но и в окрестности обучающих нейронов, т.е. нейронов

выходы которых являются обучающими входными данными на текущем шаге прогнозирования. Корректировка весов осуществляется по следующим соотношениям:

$$w_{ij}(k + 1) = w_{ij}(k) + \eta_j \cdot \sum_{i \in R_{\text{окр}}^{\text{вх}}} \eta_i \cdot y_i \quad (24)$$

$$\eta_i = \begin{cases} 1 - \frac{R_i}{R_{\text{окр}}^{\text{вх}}} & \text{для } R_i \leq R_{\text{окр}}^{\text{вх}} \\ 0 & \text{для } R_i > R_{\text{окр}}^{\text{вх}} \end{cases} \quad (25)$$

$$\eta_j = \begin{cases} 1 - \frac{R_j}{R_{\text{окр}}^{\text{вых}}} & \text{для } R_j \leq R_{\text{окр}}^{\text{вых}} \\ 0 & \text{для } R_j > R_{\text{окр}}^{\text{вых}} \end{cases} \quad (26)$$

В соотношениях 24-26:

η_j – коэффициент обучения, зависящий от удаления j -го выходного нейрона от нейрона-победителя;

η_i – коэффициент обучения, зависящий от удаления i -го входного нейрона от обучающего нейрона;

R_j – расстояние между j -м выходным нейроном и победителем;

R_i – расстояние между i -м входным и обучающим нейроном;

$R_{\text{окр}}^{\text{вых}}$ – окрестность влияния нейрона-победителя;

$R_{\text{окр}}^{\text{вх}}$ – окрестность влияния обучающего нейрона.

Расстояние между нейроном и нейроном-победителем на плоскости пространственно-закрепленной НС может определяться следующим образом:

$$R = \sqrt{R_1^2 + R_2^2} \quad (27)$$

где R_1, R_2 – расстояния в направлении первой и второй координат на плоскости пространственно-закрепленной НС.

Также могут быть применены другие метрики расстояния между нейронами.

Расстояния R_1, R_2 измеряются в количестве нейронов, отсчитываемых в соответствующем направлении от нейрона-победителя на плоскости пространственно-закрепленной НС, поэтому значения R_1, R_2 будут дискретными (1, 2, 3 и т.д.).

Обучение пространственно закрепленной НС по алгоритму, схожему с алгоритмом Кохонена, начинается с обнуления всех весов нейронов. Обучение достаточно провести в один цикл, при этом последовательность подачи обучающих субвекторов значения не имеет.

Аппроксимирующие свойства пространственно закрепленной НС можно оценить по возможности находить прогнозируемую точку между двумя известными точками, на которые НС была обучена. Вероятность нахождения промежуточной точки определим как соотношение значений на выходе нейрона, соответствующего промежуточной точке, и усредненного значения на соседних нейронах, соответствующих соседним точкам на которые НС была обучена [15].

Компьютерные эксперименты показали большую эффективность обучения при использовании степенной функции для определения коэффициента обучения η :

$$\eta = \begin{cases} 1 - \left(\frac{R_{j(i)}}{R_{\text{окр}}}\right)^2 & \text{для } R_{j(i)} \leq R_{\text{окр}} \\ 0 & \text{для } R_{j(i)} > R_{\text{окр}} \end{cases} \quad (28)$$

На рис. 8 показан график зависимости вероятности нахождения промежуточной точки $P_{\text{пр}}$ от соотношения среднего расстояния между точками на которые обучена НС $R_{\text{т}}$ и радиуса окрестности $R_{\text{окр}}$.




Рис. 8. Зависимость вероятности нахождения промежуточной точки от соотношения среднего расстояния между точками и радиуса окрестности

Полученные зависимости показывают, что применение степенной функции для задания коэффициента обучения пространственно закрепленной НС более эффективно для решения задачи аппроксимации входных данных траектории или маршрута. Для квадратичной функции оптимальное соотношение радиуса окрестности $R_{окр}$ и расстояния между точками, на которые обучена НС $R_т$ находится в диапазоне (0.8, 1).

Предложенная пространственно закрепленная НС, как показали компьютерные эксперименты, обладает способностью прогнозировать траекторию движения некоторого объекта или процесса в пространстве заданных параметров.

Выводы

В данной статье рассмотрено движение в двух координатах (на плоскости). Однако в общем случае пространство параметров в которых происходит движение

может содержать большее количество координат (гиперплоскость). Обучение и использование пространственно-закрепленной НС для прогнозирования движения в пространстве параметров любого количества координат будет осуществляться аналогичным способом, как и для прогнозирования движения на плоскости.

Обучение пространственно-закрепленной НС возможно проводить различными способами, при этом наилучшие показатели по аппроксимации достигаются при обучении способом, схожим с алгоритмом Кохонена.

Особенностью пространственно-закрепленной НС для решения задач прогнозирования движения наземных объектов по сравнению с имеющимися способами применения НС для решения таких задач является то, что она по своей топологии привязана к участку местности или пространства, на котором осуществляется прогнозирование.

Еще одной особенностью пространственно-закрепленной НС при решении задач прогнозирования является то, что она использует предысторию движения объекта (процесса) в пространстве его характеристик с необходимой заданной глубиной с учетом последовательности и направления прохождения предыдущих точек траектории.

Это дает определенные преимущества при решении задач прогнозирования, связанные прежде всего с тем, что при прогнозировании учитывается не только имеющийся образ траектории, но и то в каком участке пространства (местности) располагается рассматриваемый образ, что в общем случае имеет существенное значения для решения задачи прогнозирования.

Практическое применение пространственно-закрепленной НС представляется возможным, например, в следующих случаях:

- прогнозирование движения объекта на некотором участке земной поверхности, при необходимости осуществлять контроль за ним в военных или других целях [16-18];

- прогнозирование полета беспилотного летательного аппарата или другого воздушного объекта при дискретном поступлении данных о его координатах [19].

- прогнозирование движения объектов на морской поверхности, в том числе неуправляемых, например, айсбергов;

- прогнозирование движения объектов в пространстве, в случае сложности использования аналитической модели их движения, например прогнозирование траекторий полета стай птиц при их миграции для обеспечения безопасности полетов авиации;

- прогнозирование курсов валют или ценных бумаг в пространстве их стоимости по отношению к другим валютам и основным активам (нефть, золото и пр.).

- прогнозирование состояния сложных технических систем в пространстве их характеристик, например, состояния двигателя в пространстве характеристик: температура, давление масла, частота вращения [20];

- прогнозирование нагрузки на энергетические сети в пространстве параметров, влияющих на энергопотребление: температура воздуха, время суток, календарный день и другие параметры.

Возможно применение пространственно-закрепленной НС и в других схожих ситуациях, где требуется контролировать состояние объекта или процесса и значения характеристик, влияющих на данный объект или процесс.

Список источников

1. Васильев В.А., Федюнин П.А., Данилин М.А., Васильев А.В. Проблемные вопросы организации информационного обеспечения управления ударными авиационными комплексами // Труды МАИ. 2019. № 105. URL: <http://trudymai.ru/published.php?ID=104241>
2. Лебедев Г.Н., Мирзоян Л.А., Ефимов А.В. Выбор многоальтернативных маршрутов полета беспилотного летательного аппарата при наблюдении трассы и наземных точечных объектов на этапе планирования полета // Труды МАИ. 2011. № 48. URL: <http://trudymai.ru/published.php?ID=27150>
3. Гончаренко В.И., Желтов С.Ю., Князь В.А., Лебедев Г.Н., Михайлин Д.А., Царева О.Ю. Интеллектуальная система планирования групповых действий беспилотных летательных аппаратов при наблюдении наземных мобильных объектов на заданной территории // Известия Российской академии наук. Теория и системы управления. 2021. № 3. С. 39-56. DOI: [10.31857/S0002338821030057](https://doi.org/10.31857/S0002338821030057)
4. Бельский А.Б. Основные направления развития военных вертолетов (боевая эффективность и живучесть, функциональность, групповое и сетцентрическое взаимодействие, роботизация) // VI Всероссийская военно-научная конференции «Актуальные проблемы вооруженной борьбы в воздушно-космической сфере»: сборник трудов. - Воронеж: ВУНЦ ВВС ВВА, 2020. С. 66-75.

5. Лебедев Г.Н., Мирзоян Л.А., Ефимов А.В. Нейросетевое планирование групповых действий ЛА при наблюдении заданной группы подвижных объектов // Мехатроника, автоматизация, управление. 2009. № 11. С. 60 – 65.
6. Ананьев А.В., Иванников К.С. Динамическая модель оценки эффективности сценариев ведения воздушной разведки интегрированным пространственно-распределенным разведывательным авиационным комплексом // Труды МАИ. 2022. № 122. URL: <http://trudymai.ru/published.php?ID=164268>. DOI:
7. Ивашова Н.Д., Михайлин Д.А., Чернякова М.Е., Шаныгин С.В. Нейросетевое решение задачи оперативного планирования маршрутного полета беспилотных летательных аппаратов и назначение времени наблюдения наземных объектов с помощью нечеткой логики при отображении этих результатов на экране компьютера до вылета // Труды МАИ. 2019. № 104. URL: <http://trudymai.ru/published.php?ID=102223>
8. Ананьев А.В., Рыбалко А.Г., Иванников К.С., Клевцов Р.П. Динамическая модель процесса поражения временно неподвижных наземных целей группой ударных беспилотных летательных аппаратов малого класса // Труды МАИ. 2020. № 115. URL: <https://trudymai.ru/published.php?ID=119975>. DOI: [10.34759/trd-2020-115-18](https://doi.org/10.34759/trd-2020-115-18)
9. Соколов Д.Ю. Сравнительный анализ метода применения искусственной нейронной сети в целях решения задачи инженерно-штурманского расчета полета летательного аппарата // Вооружение и экономика. 2012. № 1 (17). С. 50-57.
10. Васильева В.И., Ильясова Б.Г., Кусимова С.Т. Нейрокомпьютеры в авиации. – М.: Радиотехника, 2004. - С. 120-180.
11. Чебатко М.И. Нейронные сети для решения задач на борту летательных

аппаратов // Зарубежная электроника. 1994. № 11-12. С. 40-44.

12. Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика, 2004. – 343 с.

13. Лебедев Г.Н., Румакина А.В. Нейросетевое планирование маршрута разновысотного полета беспилотного летательного аппарата // Авиакосмическое приборостроение. 2014. № 5. С. 3–8.

14. Галютин В.Б. Планирование маршрута полета на основе самообучения // Авиакосмическое приборостроение. 2002. № 3. С. 29-34.

15. Вентцель Е.С. Овчаров Л.А. Теория случайных процессов и ее инженерные приложения. – М.: Высшая школа, 1998. - 354 с.

16. Бельский А.Б., Сахаров Н.А. Применение аналитического метода оценки точности прицеливания в обзорно-прицельных системах вертолетов // Авиакосмическая техника и технология. 2013. № 1 (69). С. 43-46.

17. Ананьев А.В., Рыбалко А.Г., Лозарак А.В. Методика обоснования направления захода на цель на основе теории рисков при действии по наземным объектам авиационными комплексами // Труды МАИ. 2020. № 112.

URL: <https://trudymai.ru/published.php?ID=116584>. DOI: [10.34759/trd-2020-112-19](https://doi.org/10.34759/trd-2020-112-19)

18. Бельский А.Б. Основные проблемные вопросы, требования и предложения по развитию оптико-электронных систем для вертолетов военного и специального назначения // VII Международная научно-практическая конференция «Актуальные вопросы исследований в авионике: теория, обслуживание, разработки» («АВИАТОР»): сборник статей. – Воронеж: ВУНЦ ВВС ВВА, 2020. – С. 37-46.

19. Бельский А.Б. Алгоритм адаптивного сопровождения воздушных целей для прицельной радиолокационной системы перспективного боевого вертолета // Авиакосмическая техника и технология. 2018. № 1,2 (85,86). С. 67-74.
20. Андреев Д.В. Анализ и контроль уровней технических рисков на различных этапах жизненного цикла вертолётов // Труды МАИ. 2018. № 101.
URL: <https://trudymai.ru/published.php?ID=96651>

References

1. Vasil'ev V.A., Fedyunin P.A., Danilin M.A., Vasil'ev A.V. *Trudy MAI*, 2019, no. 105.
URL: <http://trudymai.ru/eng/published.php?ID=104241>
2. Lebedev G.N., Mirzoyan L.A., Efimov A.V. *Trudy MAI*, 2011, no. 48. URL: <http://trudymai.ru/eng/published.php?ID=27150>
3. Goncharenko V.I., Zheltov S.Yu., Knyaz' V.A., Lebedev G.N., Mikhailin D.A., Tsareva O.Yu. *Izvestiya Rossiiskoi akademii nauk. Teoriya i sistemy upravleniya*, 2021, no. 3, pp. 39-56. DOI: [10.31857/S0002338821030057](https://doi.org/10.31857/S0002338821030057)
4. Bel'skii A.B. *VI Vserossiiskaya voenno-nauchnaya konferentsii «Aktual'nye problemy vooruzhennoi bor'by v vozdushno-kosmicheskoi sfere»: sbornik trudov*, Voronezh, VUNTs VVS VVA, 2020, pp. 66-75.
5. Lebedev G.N., Mirzoyan L.A., Efimov A.V. *Mekhatronika, avtomatizatsiya, upravlenie*, 2009, no. 11, pp. 60 – 65.

6. Anan'ev A.V., Rybalko A.G., Ivannikov K.S., Klevtsov R.P. *Trudy MAI*, 2020, no 115. URL: <https://trudymai.ru/eng/published.php?ID=119975>. DOI: [10.34759/trd-2020-115-18](https://doi.org/10.34759/trd-2020-115-18)
7. Ivashova N.D., Mikhailin D.A., Chernyakova M.E., Shanygin S.V. *Trudy MAI*, 2019, no. 104. URL: <http://trudymai.ru/eng/published.php?ID=102223>
8. Anan'ev A.V., Rybalko A.G., Ivannikov K.S., Klevtsov R.P. *Trudy MAI*, 2020, no. 115. URL: <https://trudymai.eng/ru/published.php?ID=119975>. DOI: [10.34759/trd-2020-115-18](https://doi.org/10.34759/trd-2020-115-18)
9. Sokolov D.Yu. *Vooruzhenie i ekonomika*, 2012, no. 1 (17), pp. 50-57.
10. Vasil'eva V.I., Il'yasova B.G., Kusimova S.T. *Neirokomp'yutery v aviatsii* (Neurocomputers in aviation), Moscow, Radiotekhnika, 2004, pp. 120-180.
11. Chebatko M.I. *Zarubezhnaya elektronika*, 1994, no. 11-12, pp 40-44.
12. Osovskii S. *Neironnye seti dlya obrabotki informatsii* (Neural networks for information processing), Moscow, Finansy i statistika, 2004, 343 p.
13. Lebedev G.N., Rumakina A.V. *Aviakosmicheskoe priborostroenie*, 2014, no. 5. pp. 3–8.
14. Galyutin V.B. *Aviakosmicheskoe priborostroenie*, 2002, no. 3, pp. 29-34.
15. Venttsel' E.S. Ovcharov L.A. *Teoriya sluchainykh protsessov i ee inzhenernye prilozheniya* (Theory of random processes and its engineering applications), Moscow, Vysshaya shkola, 1998, 354 p.
16. Bel'skii A.B., Sakharov N.A. *Aviakosmicheskaya tekhnika i tekhnologiya*, 2013, no. 1 (69), pp. 43-46.
17. Anan'ev A.V., Rybalko A.G., Lozarak A.V. *Trudy MAI*, 2020, no. 112. URL: <https://trudymai.ru/eng/published.php?ID=116584>. DOI: [10.34759/trd-2020-112-19](https://doi.org/10.34759/trd-2020-112-19)

18. Bel'skii A.B. *VII Mezhdunarodnaya nauchno-prakticheskaya konferentsiya «Aktual'nye voprosy issledovaniy v avionike: teoriya, obsluzhivanie, razrabotki» («AVIATOR»): sbornik statei.* Voronezh: VUNTs VVS VVA, 2020, pp. 37-46.
19. Bel'skii A.B. *Aviakosmicheskaya tekhnika i tekhnologiya*, 2018, no. 1,2 (85,86), pp. 67-74.
20. Andreev D.V. *Trudy MAI*, 2018, no. 101. URL: <https://trudymai.ru/eng/published.php?ID=96651>

Статья поступила в редакцию 28.03.2022; одобрена после рецензирования 06.04.2022; принята к публикации 20.04.2022.

The article was submitted on 28.03.2022; approved after reviewing on 06.04.2022; accepted for publication on 20.04.2022.